第一部分

Part One

初识数据

原始数据

用户编号	计量点编号	用户地址	行业编号	时间	电量
yhbh	jldbh	yddz	xhylbdm	sjsj	dl
0800840011621380	08008400116213800001	广东省广州市...	IA0100	2017-01-01	72.60
0800150047281260	08001500472812600001	广州市番禺区...	IA0100	2017-01-01	76.00
0800840054270580	08008400542705800001	从化市鳌头镇...	IA0100	2017-01-01	73.20
0800830012924670	08008300129246700001	增城市中新镇...	IA0100	2017-01-01	79.77
0800140019640170	08001400196401700001	花都区花东镇...	IA0100	2017-01-01	76.50
0800840045312240	08008400453122400001	从化市良口镇...	IA0100	2017-01-01	79.64
0800830014194260	08008300141942600001	增城市朱村街...	IA0100	2017-01-01	79.61
0800150042859260	08001500428592600001	榄核镇雁沙村...	IA0100	2017-01-01	79.50
0800120037069980	08001200370699800002	九佛庚下九佛...	IA0100	2017-01-01	76.15
0800840011482390	08008400114823900001	从化江埔街上...	IA0100	2017-01-01	73.80

- 原始数据共 18,678,113条
- 时间跨度共709天(2017.0101-2018.12.10)
- 每天19,222—29,304条数据
- 共52,179用户;110个行业;

数据清洗

一、数据错误

- 重复记录 962条
- 3名用户缺少地址
- 1,929,395条数据存在0值记录

二、数据缺失

- 用户具有非0记录的天数: [1, 703]
- 多数用户时间不连续

三、数据不均衡

- 行业规模不均衡
- 单个用户属于单/多个行业
- 单个用户有单/多个计量点

第二部分

Part Two

相关性分析

相关性度量

01 互信息(Mutual Information)

定义了变量间相互依赖性的程度(对称)

$$I(X;Y) = H(X) - H(X|Y) = \sum_{x,y} p(x,y) log \frac{p(x,y)}{p(x)p(y)}$$

02 转移熵(Transfer entropy)

定义了两个随机过程的信息传递量(不对称)

$$T_{X\to Y} = H(Y_t|Y_{t-1:t-L}) - H(Y_t|Y_{t-1:t-L}, X_{t-1:t-L})$$

03 皮尔森相关系数(Pearson Correlation Coefficient)

定义了变量间的直接相关性(对称)

$$\rho = \frac{\mathrm{cov}(X,Y)}{\sigma_X \sigma_Y} = \frac{E[(X-\mu_X)(Y-\mu_Y)]}{\sigma_X \sigma_Y}$$

计算准备

一、数据过滤

- 过滤记录天数≤200天的用户，并去重
- 过滤数据中存在用电量为0的记录
- 取各行业中日均用电量前五的用户，共105*5=490用户
- 其中大部分用户有大于400/709的用电量记录

二、数据补全

- 时间序列对齐，并通过插值补全某些日期缺少电量记录的数据

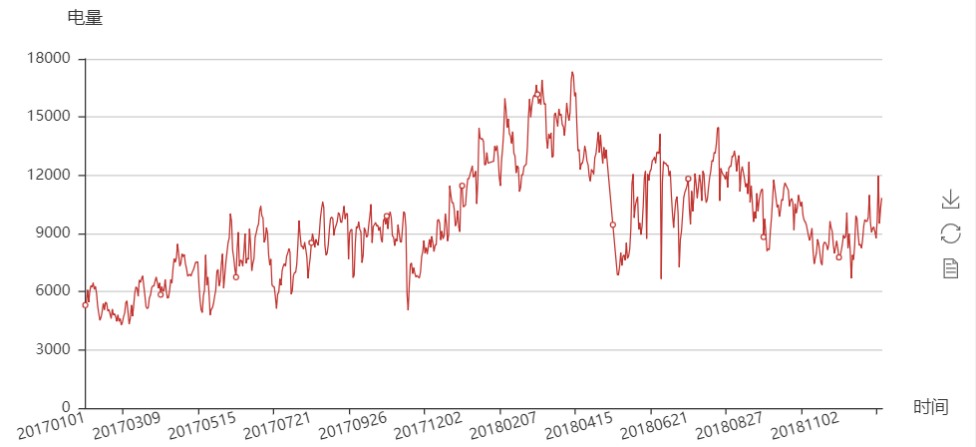

计算结果

一、相关性分析

- 通过线性插值补全计算的MI分布(左图)：[7.98×10^{-6}, 2.27]
- 通过线性插值补全计算的TE分布(右图)：[0, 0.247]

(-0.00226, 0.227]	136065
(0.227, 0.454]	82240
(0.454, 0.681]	16802
(0.681, 0.908]	3989
(0.908, 1.135]	512
(1.135, 1.362]	32
(1.362, 1.589]	20
(1.589, 1.816]	69
(1.816, 2.043]	185
(2.043, 2.27]	186

MI

(-0.000247, 0.0247]	15524
(0.0247, 0.0494]	19018
(0.0494, 0.0741]	57537
(0.0741, 0.0989]	54686
(0.0989, 0.124]	44556
(0.124, 0.148]	31838
(0.148, 0.173]	13605
(0.173, 0.198]	2706
(0.198, 0.222]	566
(0.222, 0.247]	64

TE

二、数据异常

- 个别用户存在某些事件用电量异常高/低的情况
- 如用户'0800150005485840'，687天中686天用电量范围为[11.52,67.87]，2017.08.18当天用电44143.03

第三部分

Part Three

研究问题

研究问题

（暂定）

一、问题概述

- 行业用电量相关性分析

二、研究内容

- 各行业两两间用电量的总相关性：
  - （1）行业间用电量相关性
  - （2）行业内用电量相关性
- 时序相关性：
  - （1）两用户的用电量相关性是否随时间变化
- 空间相关性：
  - （1）地理位置相近的用户相关性是否更强
  - （2）处于特殊区域的用户是否会对其他用户产生更大影响
  - （3）地理位置的周边设施分布是否对相关性有影响

研究方法

（暂定）

一、相关性计算

- 通过划分时间窗的方式，计算用户两两间的相关性

二、动态图构建

- 静态图构建：

  （1）节点表示用户，边表示具有连接的两个用户具有强相关性

  （2）一张静态图表示一个时间窗范围内，用户用电量的相关性关系

  （3）必要时可以对节点聚合，将一个行业的用户聚合为一个节点

- 动态图构建：

  （1）将一系列静态图按照时间顺序排列/连接

  (2) 通过行业、地理位置关系两种信息对图布局增加限制

研究方法

（暂定）

三、可视分析

- 各行业用电量统计（统计图表）
- 各行业用电量相关性总览（关系矩阵等）
- 动态图总览与分析（图可视化）
- 用户地理位置关系分析（地图）

第四部分

Part Four

任务安排

人员安排

一、人员安排

任务	人员
项目经理	卢金璇、陈则衔
前端实现	费治军
后端实现	路文杰

二、进度安排

4.1-4.15　进一步明确研究方法

完成系统前后端框架搭建

尝试构建动态图网络

前后端技术调研

4.16-4.30　完成前端基础模块构建

同步实现前后端数据接口

5.1-5.15　完成项目

绿色：已完成

红色：未完成

人员安排

三、4.3-4.10任务安排

路文杰：

（1）调研并学习JAVA后端技术

（2）进行后端搭建

（3）使用样例数据（490用户）计算划分时间窗的相关性变化

（4）后端需要传往前端的数据包括：用户/行业用电量、用户/行业两两间一段时间内的总相关性与相关性变化、动态图的拓扑结构等。

费治军：

（1）调研并学习前端技术，React、D3.js等

（2）进行前端框架搭建

（3）调研百度、高德地图api（用户数据目前只有中文地址，需要通过api转化为经纬度）

（4）绘制样例数据的相关性变化情况（折线图）

人员安排

三、4.10-4.17任务安排

总进度：

1.项目前后端搭建并整合完毕，使用git管理代码（费治军、路文杰）

后端(路文杰)：

（1）计算动态图的拓扑结构

前端(费治军、卢金璇)：

（1）绘制静态图结构（力引导）

（2）动态图投影（参考reducing snapshots to points）

（3）前后端接口整理

（4）地图：根据上周调研情况安排工作

卢金璇：

（1）阅读有关相关性分析的数据挖掘论文

人员安排

三、4.19-4.24任务安排

后端(路文杰、卢金璇)：

（1）数据接口（路）

（2）动态图投影计算（卢）

前端(费治军、卢金璇)：

（1）完成界面结构

（2）完成地图

（3）根据上周进度完成动态图投影绘制

卢金璇：

（1）阅读有关相关性分析的数据挖掘论文

系统界面

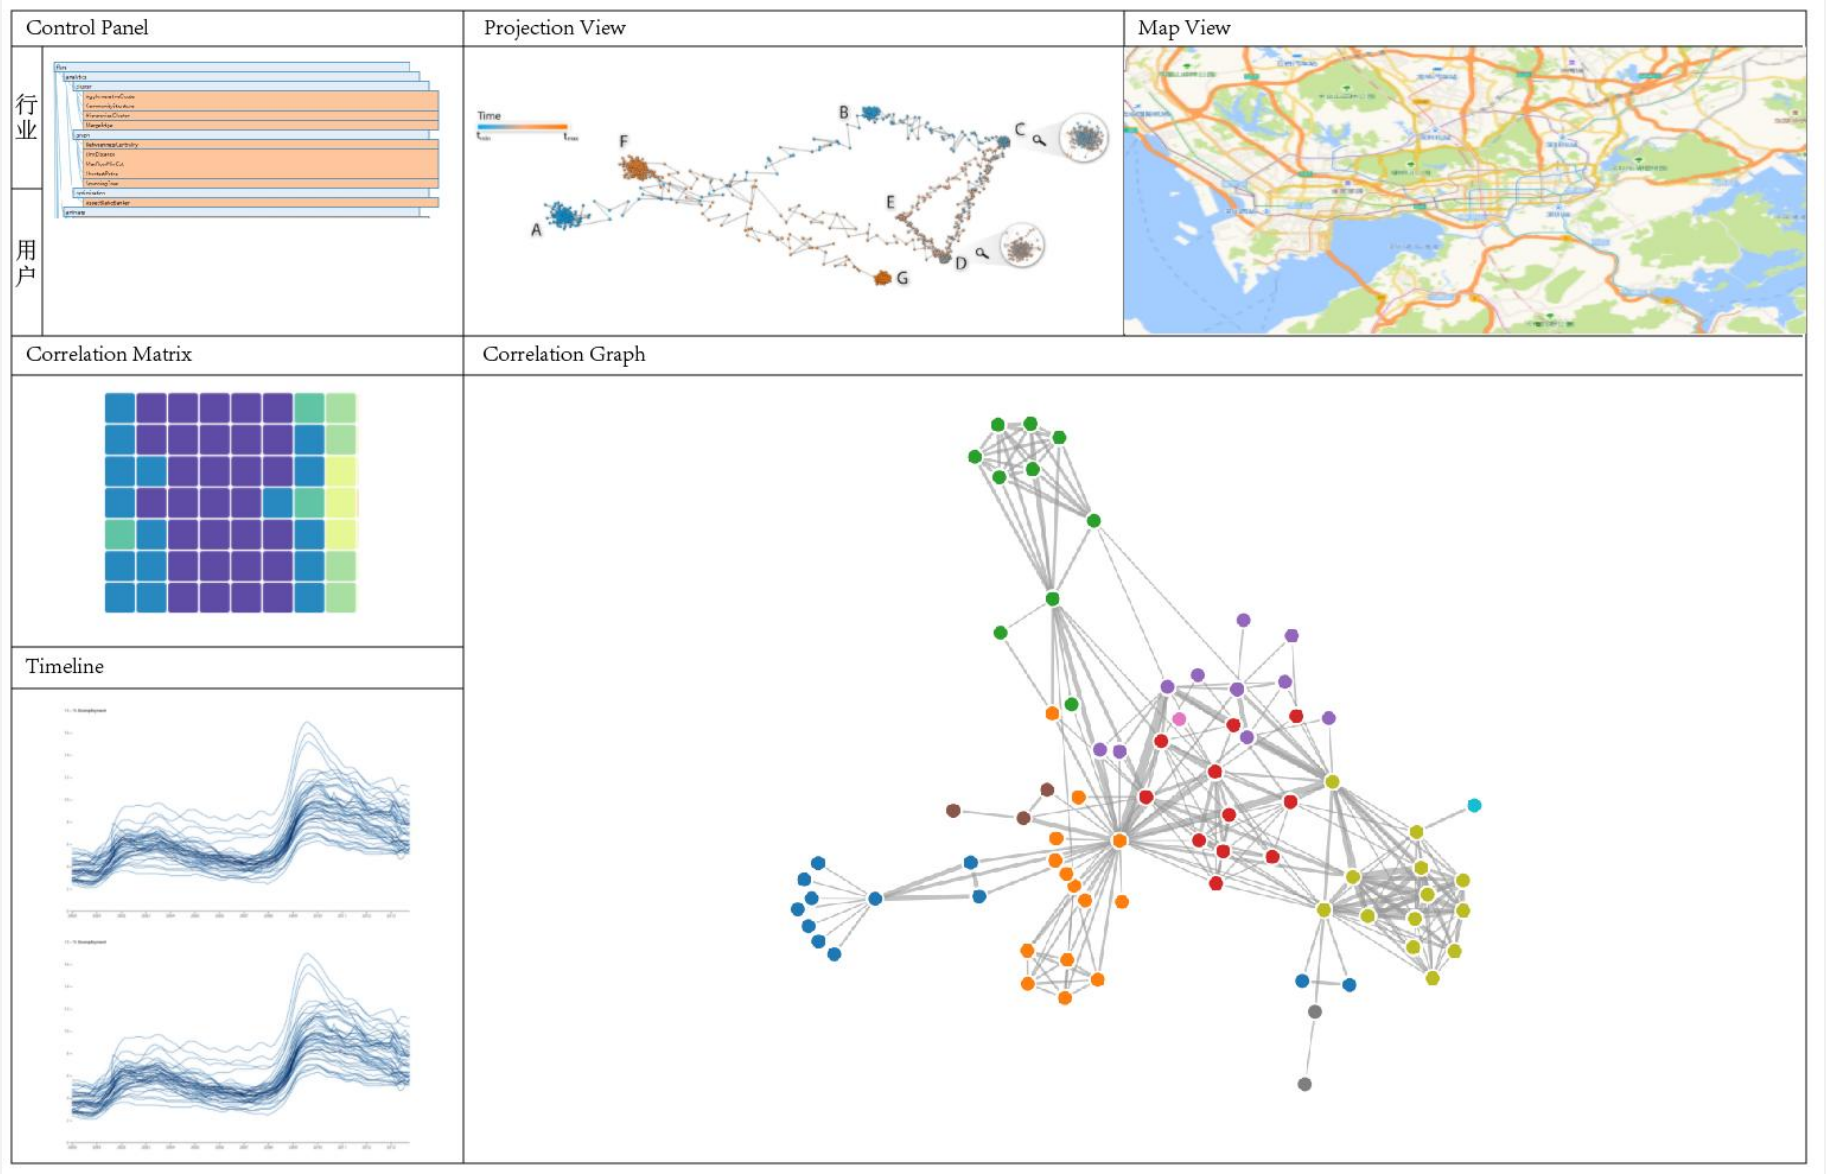
Control Panel
行业
用户
Projection View
Time
A
B
C
D
E
F
G
Map View
Correlation Matrix
Correlation Graph
Timeline